

**SVEUČILIŠTE U ZAGREBU  
FILOZOFSKI FAKULTET  
ODSJEK ZA SOCIOLOGIJU  
Ak. god. 2018. / 2019.**

*DIPLOMSKI RAD*

***DRUŠTVENE IMPLIKACIJE RAZVITKA UMJETNE  
INTELIGENCIJE***

*LEJLA GHAZZAWI*

Mentor: dr. sc. Krešimir Žažar

Zagreb, studeni 2018.

# ***DRUŠTVENE IMPLIKACIJE RAZVITKA UMJETNE INTELIGENCIJE***

## **SAŽETAK**

Umjetna inteligencija je simulacija strojeva, specifično računalnih sustava da imitiraju ponašanje ljudskih obavještajnih procesa. Ti procesi uključuju učenje (stjecanje informacija i pravila za korištenje informacija), obrazloženje (pomoću pravila za postizanje približnih ili definitivnih zaključaka) i autonomnosti. Vrlo su bitne metode koje se koriste prilikom programiranja autonomnih strojeva kako bi kod bio što više funkcionalan te izvršavanje krajnjih naredbi. Kroz povijest vidimo kako je napredovalo razvijanje područja umjetne inteligencije, poseban je naglasak na neuralnim mrežama koje su u svojim počecima bile temelj programiranja sustava umjetne inteligencije no ostale su to i dan danas. Posebne primjene umjetne inteligencije uključuju ekspertne sustave, prepoznavanje govora i lica. Neki stručnjaci se bave teorijom jake umjetne inteligencije prema kojoj postoji mogućnost da će strojevi s vremenom uspjeti razviti vlastita razmišljanja i samosvijest, dok većina akademske zajednice smatra da je takav razvoj događaja nemoguć jer su ljudi ti koji programiraju strojeve. Postavlja se pitanje na koje će sve načine tehnologija umjetne inteligencije utjecati na suvremeno društvo, u kojim će sve područjima djelovati te kako će ju pojedinci prihvatiti. Kroz nekoliko primjera ćemo vidjeti kakva su trenutno mišljenja i stajališta o takvom napretku, iz perspektive znanstvenika i laika. Bitno je i baviti se pitanjima moralnosti i etičnosti, tj. na koje će se načine moći regulirati bilo kakva vrsta zlouporabe ili manipulacije pomoću umjetne inteligencije.

**Ključne riječi:** umjetna inteligencija; stroj; ekspertni sustavi; neuralne mreže

## ***SOCIAL IMPLICATIONS OF DEVELOPMENT OF ARTIFICIAL INTELLIGENCE***

### **SUMMARY**

Artificial Intelligence is a simulation of human intelligence processes of machines, specifically computer systems. These processes include learning (learning information and rules for use of information), explanation and autonomy. It is very important which methods are used in programming autonomous machines to be as functional and executable as possible. Throughout history we see progress in the development of the field of artificial intelligence, there is especially the emphasis on neural networks that were initially the basis for the programming of the artificial intelligence system, and they still are today. Special applications of artificial intelligence include expert systems, speech and face recognition. Some experts are concerned with the theory of strong artificial intelligence that there is a possibility that machines will eventually develop their own thinking and self-consciousness, while most academic communities believe that such a development is impossible because people are those who program machines. It raises the question of how will artificial intelligence affect modern society, in which areas will it perform and how will individuals accept it. Through few examples, we will see what are current standpoints and opinions about such progress, from the perspective of scientists and laymen. It is also important to deal with questions of morality and ethics, in what way will we be able to regulate any kind of abuse or manipulation by artificial intelligence.

**Keywords:** artificial intelligence; machine; expert systems; neural networks

# SADRŽAJ

<b>SAŽETAK.....</b>	<b>2</b>
<b>SUMMARY.....</b>	<b>3</b>
<b>1. UVOD .....</b>	<b>7</b>
1.1. Predmet, cilj i struktura rada .....	7
<b>2. UMJETNA INTELIGENCIJA .....</b>	<b>8</b>
2.1. Jaka umjetna inteligencija .....	11
2.2. Slaba umjetna inteligencija .....	12
<b>3. KRONOLOGIJA POVIJESNOG ISTRAŽIVANJA UMJETNE INTELIGENCIJE .....</b>	<b>13</b>
<b>4. PRIMJENJENE METODE U UMJETNOJ INTELIGENCIJI .....</b>	<b>18</b>
4.1. Klasične metode u umjetnoj inteligenciji .....	18
4.2. Suvremene metode u umjetnoj inteligenciji .....	19
4.2.1. Neuralne mreže .....	20
<b>5. BUDUĆE IMPLIKACIJE RAZVOJA UMJETNE INTELIGENCIJE .....</b>	<b>23</b>
5.1. Automatizacija prijevoza.....	23
5.2. Implementacija umjetne inteligencije u svakodnevni život .....	27
5.3. Emocionalna veza između ljudi i strojeva.....	30
5.4. Umjetna inteligencija u Hollywoodu .....	32
<b>6. ZAKLJUČAK.....</b>	<b>33</b>
<b>7. POPIS LITERATURE.....</b>	<b>35</b>

# 1. UVOD

## 1.1. Predmet, cilj i struktura rada

Predmet rada su društvene implikacije razvitka umjetne inteligencije. Cilj rada je objasniti čime se bavi područje umjetne inteligencije, ukratko opisati neke osnovne pojmove te obrazložiti razliku između slabe i jake umjetne inteligencije. Zatim ćemo u par točaka iznijeti kronologiju povijesnog nastanka umjetne inteligencije koja, prema nekim mišljenjima, svoje početke pronalazi još u antici. Isto tako analizirat će se trenutno stanje umjetne inteligencije na način da se usporede klasične i suvremene metode koje se temelje na proučavanju neurona u ljudskom mozgu i to na način da stvaraju umjetne neurone koji imaju sve karakteristike stvarnih, bioloških neurona. Nadalje, bit će izložena i stajališta stručnjaka koji su radili i istraživali na području umjetne inteligencije, govorit će se o tome što se očekuje u bliskoj budućnosti po pitanju umjetne inteligencije, odnosno na koji način će ista olakšati svakodnevne aktivnosti u životu čovjeka, kako će generalno utjecati na suvremeno društvo, kakvi su rezultati nekih istraživanja provedenih o mišljenjima i stavovima pojedinaca o umjetnoj inteligenciji u poslovnoj i privatnoj sferi te jesu li opravdani neki strahovi koje donose predrasude o umjetnoj inteligenciji. Kroz par primjera ćemo prikazati kakve su inovacije do sada stvorene, u kojem smjeru idu trenutna istraživanja te koliko se brzi napredak očekuje.

Diplomski rad pod naslovom "Društvene implikacije razvitka umjetne inteligencije" podijeljen je u šest poglavlja. Prvo poglavlje, „Uvod“, govori o predmetu i cilju rada, izvoru podataka te iznosi kratak sadržaj i strukturu rada. Drugo poglavlje, „Umjetna inteligencija“, definira pojam umjetne inteligencije iz perspektive brojnih znanstvenika, kao i karakteristike slabe i jake umjetne inteligencije. Treće poglavlje, „Kronologija povijesnog istraživanja umjetne inteligencije“, govori o povijesnom nastanku umjetne inteligencije od antičkog vremena pa do danas, način na koji se razvoj umjetne inteligencije razvija. Četvrto poglavlje, „Primijenjene metode u umjetnoj inteligenciji“ se bavi klasičnim i suvremenim metodama koje su korištene na tom području. Peto poglavlje, „Buduće implikacije razvoja umjetne inteligencije“, upućuju na razvoj umjetne inteligencije u našoj bliskoj budućnosti te kakav će utjecaj ista imati na obavljanje svakodnevnih ljudskih aktivnosti. Šesto poglavlje, „Zaključak“, je sinteza svega prikupljenog u radu. Na kraju rada se nalazi popis relevantne literature koja je korištena prilikom pisanja rada.



## 2. UMJETNA INTELIGENCIJA

Neopisivo brz napredak tehnologije sveprisutan je i vrlo uočljiv na svakom koraku. Suvremena tehnologija nam je pokazala za što je sposobna iako još nismo vidjeli sva njena lica no evidentni su nevjerojatni pomaci na području umjetne inteligencije, koju mnogi smatraju najmoćnijom tehnologijom čovječanstva.

Postoji puno definicija umjetne inteligencije. S obzirom na to da se radi o vrlo širokom i sveobuhvatnom području, teško je izdvojiti jednu kao točnu, no ono oko čega se svi slažu jest da je ona kreirana da oponaša biološku konstrukciju i rad ljudskog mozga.

Stuart J. Russell i Peter Norvig (2010) definiraju pojam umjetne inteligencije kao nauku o „agentima“ (izvršiteljima) koji primaju opažanja iz okoline i pretvaraju ih radnju. U svojoj knjizi opisuju na čemu se temelji primarno područje suvremenih metoda dizajniranja i programiranja umjetne inteligencije, a to su umjetne neuralne mreže<sup>1</sup>. Dakle, to je model koji oponaša biološku neuralnu mrežu te kao rezultat dobivamo zastupanje znanja u velikim paralelnim procesiranjima, brz povrat velikog broja informacija te sposobnost prepoznavanja uzorka temeljenih na iskustvu.

McCarthy (2007) smatra da je umjetna inteligencija sposobnost digitalnog računala ili računalno-kontroliranog robota da izvodi zadaće obično povezane uz inteligentna bića. Drugim riječima, prema McCarthyu, umjetna inteligencija je znanost i inženjering za izradu inteligentnih strojeva, osobito inteligentnih računalnih programa, a radi se o sličnom zadatku korištenja računala za razumijevanje ljudske inteligencije, ali se umjetna inteligencija ne mora ograničiti samo na metode koje su usmjerene samo na proučavanje funkcioniranja ljudskog mozga. Općenito kada u tom smislu govorimo o inteligenciji, McCarthy inteligenciju smatra „dijelom računalne sposobnosti postizanja ciljeva u svijetu“ (McCarthy, 2007: 2).

Umjetna inteligencija shvaća se kao inteligentni entitet, stoga se zasigurno može reći da je jedan od razloga, odnosno svrha istraživanja umjetne inteligencije razumijevanje ljudskog postojanja i funkcije mozga. Kada bismo pogledali sa filozofskog ili psihološkog stajališta može se reći da je cilj provođenja istraživanja umjetne inteligencije izgradnja umjetnih inteligentnih entiteta.

---

<sup>1</sup> Eng. *Neural networks* – u hrvatskom jeziku se koriste izrazi „neuralne“ i „neuronske“ mreže, u ovom radu ćemo koristiti izraz „neuralne“ mreže.

Russell i Norvig (2010) tvrde da umjetna inteligencija propituje jednu od konačnih zagonetki, odnosno kako tako mali organ poput mozga može percipirati i razumjeti svijet koji je mnogo veći i kompleksniji od njega samoga. Tek onda dolazi do pitanja kako je moguće stvoriti nešto što ima takva svojstva, no istraživači su već do sad dokazali da je taj zadatak moguće ostvariti.

Gbenoukpo Singbo (2009) je u svom radu "*Umjetna inteligencija u suvremenom kibernetičkom sustavu*" sažeo Russellove i Norvigove definicije u nekoliko kategorija, a to su: sustavi koji misle poput čovjeka, koji se ponašaju kao čovjek, koji misle racionalno, koji se ponašaju racionalno, koji imaju sve osobine racionalne ili ljudske inteligencije te oni čije unutarnje funkcioniranje pokušava biti u skladu s ljudskim, odnosno racionalnim bićem.

Isto tako može se reći da sva dosadašnja istraživanja koja su provedena na temu umjetne inteligencije imaju dva temeljna cilja:

1. izgradnja inteligentnih strojeva (roboti),
2. pokušaji da se razumije prirodna inteligencija (različitim testovima inteligencije kojima se mjeri generalna inteligencija, a provode se s ciljem utvrđivanja pojedinačnih sposobnosti).

Kada je riječ generalnoj umjetnoj inteligenciji (eng. *Artificial General Intelligence*, skraćeno AGI) tada se govori o istraživanjima koja su usmjerena na tehnološko kreiranje strojeva koji su osposobljeni za obavljanje određenih radnji.

Isto tako jedan od osnovnih ciljeva generalne umjetne inteligencije je ovladati različitim područjima kako bi se smanjili sati ljudskog rada i pritom olakšale brojne aktivnosti. Kada govorimo o generalnoj umjetnoj inteligenciji u odnosu na čovjeka tada se govori o potencijalnoj sposobnosti za rješavanje problema, koja je urođena, ali ujedno ovisi i osposobljenosti pojedinca za rješavanje problema. Drugim riječima, nije poanta da generalna umjetna inteligencija vlada jednakim sposobnostima u svim područjima i segmentima ljudskog postojanja, već to da bude u stanju savladati različita područja te naučiti o područjima s kojima se prije nije nikada suočila.

Brojni znanstvenici koji su radili na razvoju područja umjetne inteligencije govore o strojevima u smislu umjetne inteligencije, ali u osnovi postoji jako mali broj njih koji su i suglasni s inovacijom strojeva kojima je glavni način funkcioniranja taj da imitiraju rad ljudskog mozga. „To ima za posljedicu da je među istraživačima veoma malo suglasnosti o



tome što umjetna inteligencija stvarno jest i što bi trebala biti. Složni su u tome da strojevima žele podariti atribute koje nisu u stanju definirati. Stoga umjetna inteligencija pati od nedostatka definicije svog područja djelovanja, a istraživanja umjetne inteligencije fokusirana su uglavnom na komponente inteligencije kao što su učenje, zaključivanje, rješavanje problema, percepciju te uporabu jezika“ (Schank, 1993: 4).

Prema Rogeru C. Schanku (1993) postoji nekoliko značajki inteligencije. Neke od njih su: komunikacija, koja je moguća samo između inteligentnih subjekata, može se odnositi na različite vrste inteligencije, primjerice poput komunikacije između čovjeka i psa. Druga od tih značajki je unutarnje znanje, koje se temelji na pretpostavci da inteligentni entitet ima neko znanje o sebi. Očekuje se da taj entitet zna kada mu je nešto potrebno, mora o nečemu misliti i biti svjestan da o tome misli. Treća značajka je znanje o svijetu, koja se odnosi na pretpostavku da postoji svjesnost inteligencije o vanjskom svijetu te da ima sposobnost pronalaziti te koristiti informacije koje postoje o vanjskom svijetu, što ujedno znači i posjedovanje memorije u kojoj se nalaze prošla iskustva i koja se mogu koristiti kao vodič za procesiranje novih iskustava. Ciljevi i planovi su četvrta značajka koja se referira na ponašanje koje je orijentirano prema cilju, tj. razumijevanja onog što se želi postići i prepoznavanja načina za postizanje toga cilja. Ono što je bitno u samom planiranju jest da međuodnos planova i njihova pohrana budu adekvatni kako bi se uspjeli rješavati raznoliki oblici problema, odnosno da plan koji je kreiran za situaciju A, bude adekvatan, odnosno usvojen i primjenjiv na situaciju B. Primjerice ukoliko autonomno vozilo uči voziti na poligonu nekog parkirališta, trebalo bi biti sposobno primijeniti naučeno znanje i na otvorenu cestu. Prema dotadašnjem vlastitom iskustvu bi trebao s vremenom biti više prilagođen na sve više različitih okruženja i snaći se na bilo kojem terenu, gustoći prometa, vremenskim uvjetima i sl. jer bi sam trebao nadograđivati svoje programiranje pomoću usvojenih informacija koje je dobivao u različitim situacijama.

Kreativnost postoji u svim inteligentnim entitetima, samo što se očitava u različitim razinama i stupnjevima. Kreativnost je samu po sebi teško definirati, između ostalog, možemo ju opisati kao sposobnost snalaženja u novonastalim situacijama, odnosno korištenje već naučenih znanja i vještina te njihovo adekvatno primjenjivanje u trenucima kada je to potrebno. Također može značiti i drugačiji pogled na svijet oko sebe, tj. različite kutove gledanja i perspektive, što može predstaviti neka inovativna stajališta i temelj za učenje novih znanja i vještina te otkrića temeljena na dosad neviđen način koja mogu omogućiti razvijanje novih sposobnosti primjenjivih na raznolike situacije. “Kreativnost prije svega znači

sposobnost prilagodbe na promjene u okolini te sposobnost učenja iz iskustva. Možemo reći kako entitet koji ne uči vjerojatno nije inteligentan” (Schunk, 1993: 6).

Dakle, možemo zaključiti da je stroj inteligentan onoliko koliko smo ga mi sposobni naučiti. Tu nailazimo na razilaženje razmišljanja stručnjaka oko činjenice koliko kreativan i sposoban stroj može biti ili postati. S vremenom su se razvili pojmovi jake i slabe umjetne inteligencije koji se temelje na potencijalima koje program tj. stroj može realizirati i u kojoj mjeri.

## **2.1. Jaka umjetna inteligencija**

Koncept jaka umjetna inteligencija ili svjesna umjetna inteligencija je 1980. predstavio filozof John Searle u svojem istraživanju na Kalifornijskom sveučilištu na Berkleyu. Prema Searleu (1980) taj se pojam odnosi na stroj koji ne bi bio samo sposoban izvoditi inteligentno ponašanje, nego bi čak dao dojam realne samosvijesti, istinitih osjećaja, i razumijevanja vlastitih rasuđivanja.

Searle je bio izložen negativnim kritikama na iznošenje svog stajališta o jakoj umjetnoj inteligenciji. Dvije godine nakon objavljivanja Searleovog članka „*Minds, Brains, and Programs*“, Dennett (1982) je iznio negativno mišljenje o tom članku te je krenulo u njihovo prepiranje kroz nekoliko objavljenih članaka. Dennett se ne slaže sa Searleom da je moguće da strojevi imaju 'um' ili 'razum'. Kaže da je moguće da stroj ima neke odlike mozga, no to bi se više smatralo nekom vrstom proteze mozga, a ne stvarnog ljudskog mozga sa svim biološkim funkcijama.

Jaka umjetna inteligencija je u znanstvenoj zajednici potaknula brojne rasprave i podvojena mišljenja. Kritičari dan danas ne vjeruju u mogućnost ostvarivanja takve vrste umjetne inteligencije s obzirom da se o toj temi raspravlja još od 1950-ih, a da napredak na tom području, prema njihovom mišljenju, nije bio dovoljno velik ni značajan.

Smatram da jaka umjetna inteligencija neće biti realizirana u skoroj budućnosti. Slažem se s mišljenjima stručnjaka da to nije područje oko kojeg bismo trebali biti zabrinuti. Sam koncept je zanimljivo iskoristiti za neku priču znanstvene fantastike, ali u stvarnom svijetu nije moguće da strojevi razviju vlastitu svijest ili da razviju empatiju jer su sustavi dobri koliko su i njihova pravila, a pravila mu postavljaju i zadaju ljudi i ograničava suvremena tehnologija, koja i dalje nije dovoljno napredna da bi omogućila takav razvoj.

## **2.2. Slaba umjetna inteligencija**

Za razliku od jake, za koju se polazi od pretpostavke da će samostalno razmišljati, slaba umjetna inteligencija je puno realnija i izvediva jer samo simulira ljudsko razmišljanje, ponaša se kao da je inteligentna (Russell, Norvig, 2010). Temelji se na pretpostavci da bilo koji aspekt učenja ili nekog drugog svojstva inteligencije može biti točno opisana kako bi ju stroj mogao oponašati odnosno simulirati. Svi oblici umjetne inteligencije koji su do sada izumljeni pripadaju u ovu kategoriju jer zasada nemaju vlastito razumijevanje niti svijest.

Russell i Norvig (2010) tvrde da ostvarivost i neostvarivost umjetne inteligencije ovisi o tome kako je definirana. Isto tako smatraju da se svi istraživači i izumitelji moraju zapitati oko etičkih implikacija svojih radova, bez obzira na to kako nazivaju tu vrstu umjetne inteligencije. Iako većini njih nije bitno kako je točno nazivaju, već da li je njihov program funkcionalan te da li će raditi prema njihovoj zamisli.

### 3. KRONOLOGIJA POVIJESNOG ISTRAŽIVANJA UMJETNE INTELIGENCIJE

Prema Gbenoukpo Singbou (2009) povijesni razvoj umjetne inteligencije može se pratiti kronologijom sljedećih događaja:

- 1943: McCulloch i Pitts osnivaju model formalnog (umjetnog) neurona. Iako su imali značajan utjecaj, u to doba njihovo istraživanje nije pridobilo previše pažnje. Dali su doprinos u formalizmu usavršavanja i generalizacije koji su doveli do finalnog viđenja automatizacije, vrlo bitnog formalizma u teoriji izračunavanja. Uveli su tehniku koja je inspirirala pogled na logični dizajn, prvi su koristili izračunavanje koji su bili upućeni na probleme vezane uz tijelo i um te su doprinijeli suvremenoj teoriji računanja uma i mozga (također vidjeti i Piccinini, 2004).
- 1948: Norbert Wiener osniva kibernetiku (znanost sustava). To je bila nova znanost koja objedinjuje teoriju komunikacija i teoriju upravljanja te obuhvaća ljudski um, ljudsko tijelo i svijet automatiziranih strojeva. Pojam kibernetika se odnosi na hibrid čovjeka i stroja, odnosno na ljudsko-strojni sustav sa samoregulacijom (također vidjeti i Wiener, 1964).
- 1949: D. Hebb sastavio je prva pravila učenja neuronskih mreža. Postavio je temelje razvoja mehanizma učenja mreža, tzv. Hebbovo učenje, odnosno učenje kao metabolička promjena u neuronima, temelji se na postulatu koji je Hebb postavio kako bi fiziološki objasnio rad živčanog sustava (također vidjeti i Hebb, 1949). Kad je akson neurona A dovoljno blizu da aktivira neuron B to ponavlja veći broj puta, dolazi do metaboličkih promjena tako da se povećava efikasnost neurona A u aktiviranju neurona B (Hebb, 1949: 62). Stoga se Hebbovo učenje može primijeniti za učenje povezanosti između dva skupa uzoraka u kojem svaki skup uzoraka predstavlja aktivaciju nekog od neurona.
- 1950: Shannon, 1952: Samuel, 1953: Turing: računalo koje igra šah na reduciranoj ploči.<sup>2</sup>
- 1951: M. Minsky i D. Edmonds: prvo računalo temeljeno na neuronskoj mreži SNARC, Stochastic Neural Analog Reinforcement Calculator, stroj neuralnih mreža

---

<sup>2</sup> Turing je posebice imao velikog utjecaja na polju umjetne inteligencije, no o njemu ćemo malo opširnije u daljnjem tekstu.

koji je umrežen s četrdesetak Hebbovih sinapsi. Iako su Minskyjevi radovi nailazili na skeptična mišljenja, s vremenom se pokazalo da su njegovi radovi bili vrlo utjecajni na daljnji razvoj istraživanja neuralnih mreža (također vidjeti i Russell, Norvig, 2010).

- 1956: Radionica tijekom koje se rodio pojam *umjetne inteligencije*.<sup>3</sup>
- 1958: J. McCarthy: razvoj programskog jezika LISP, *time sharing* i „Digital“; F. Rosenblatt: Perceptron, koji je bio probabilistički model za pohranu informacija i organizaciju u mozgu. Teorija je bila temeljena na poveznici između biofizike i psihologije te stvoren algoritam za učenje uz nadzor (eng. *supervised learning*) binarnih klasifikatora. Binarni klasifikator je funkcija pomoću koje se odlučuje da li unos pripada ili ne pripada nekoj određenoj klasi.
- 1959: Rochester je sa svojim kolegama proizveo neke od prvih programa umjetne inteligencije. N. Rochester je konstruirao „Geometry Theorem Prover“, koje bio sposoban dokazati teoreme koji su bili teški za većinu studenata matematike (također vidjeti i Russell, Norvig, 2010).
- 1960: J. McCarthy, Allen Bewell i Herbert Simon: dolaze do spoznaje da računalo može biti korišteno za druge stvari osim računanja, a to je manipulacija simbolima slijeđenjem fiksnih i formalnih pravila. Simboli imaju istaknutu ulogu u vrstama kognitivnih zadataka kao što su matematički izračuni i logičko zaključivanje.
- 1961: L. Samuel je napravio šahovski program koji igra šah na razini majstora. S vremenom je time dokazao da računalo ne radi samo ono što mu se kaže jer je računalo vrlo brzo naučilo igrati bolje od svog tvorca.
- 1965: A. Robinson: uporaba rezolucije kao metode logičkog zaključivanja; Lederberg, Feigenbaum i Djerassi su započeli rad na glasovitom ekspertnom sustavu „Dendral“, njegova posebnost je proizlazila iz toga što je njegova stručnost proizlazila iz velikog broja pravila posebnih svrha. „Dendral“ je bio korišten kao ekspertni sustav za kemijske analize, kao pomoć kemičarima da mogu ustvrditi strukturu organskih molekula. S vremenom se počeo upotrebljavati McCarthyjev pristup, da se u obliku razdvoje komponente znanja od komponenta prosudbe ili rasuđivanja (također vidjeti i Russell, Norvig, 2010).
- 1969–1979: pojava ekspertnih sustava.
- Od 1986. do danas: korištenje neuralnih mreža, na kojima se temelje i današnji radovi i sustavi na području umjetne inteligencije.<sup>4</sup>

---

<sup>3</sup> O toj temi ćemo također malo više reći na sljedećim stranicama rada.

Ovaj pregled nam prikazuje neke relevantne napretke na području umjetne inteligencije te možemo zaključiti kako se u današnje vrijeme koriste metode koje su zapravo bile otkrivene već u samom početku razvijanja tehnologije umjetne inteligencije, no ona ne bi imala neko usmjerenje niti toliki napredak bez svih otkrića koje su se dogodile u desetljećima istraživanja i otkrivanja novih mogućnosti. Također možemo primijetiti kako mišljenja nekih znanstvenika na tom području nisu bila prihvaćena u samom početku, nego su s vremenom dobila na značaju tek kad je došlo do nekih novih otkrića i spoznaja.

Calum Chace (2015) u svojoj knjizi „*Surviving AI: The promise and the peril of artificial intelligence*“, povijest umjetne inteligencije prikazuje u sedam faza:

- 1) Grčki mitovi – kaže da su dokazi za umjetnom inteligencijom postojali još u vrijeme bogova. Za primjer je uzeo mit o Hefestu koji je izrastao u obrtnika te je svoje vještine koristio da služi bogovima. Chace kaže da su Hefestove kreacije bile napravljene od metala ali da su imale raznovrsne namjene. Također je i izumio kolica za pića koja su se samostalno pokretala te vraćala na početnu poziciju. U Aleksandrijskoj knjižnici su pronađeni zapisi o proučavanju matematike i mehanike automatizma te studije o programiranju samohodnih strojeva.
- 2) Prva znanstvena fantastika (razdoblje između 1820-ih i 1920-ih) – „Frankenstein and Rossum’s Universal Robots“ (RUR) – Chace tvrdi da se u tim djelima prvi put prikazuje kako se ljudski izumi i napredak čovječanstva može okrenuti protiv nas. RUR govori o tome kako su roboti zavladaali svijetom i izbrisali cijelo čovječanstvo osim jednog čovjeka te su potom otkrili da im se razvijaju ljudske emocije. Ti roboti su bili Androidi koji su imali ljudski oblik te sposobnost samostalnog razmišljanja.
- 3) Charles Babbage i Ada Lovelace – Babbageov izumi su uvelike doprinijeli razvoju mehanike, matematike te mnogih drugih znanosti. Izumio je Diferencijalni stroj 1822. godine, koji je bio namijenjen računanju tablica te aproksimaciju. Izumio je i Analitički stroj kojim je htio je ukloniti nedostatke dosadašnjih mehaničkih računala, sadržao je i programski jezik zahvaljujući algoritmima koje je kreirala Ada Lovelace (Ada Byron). Kao osnovnu bazu je koristio binarni sustav, imao je procesor, jedinicu za pohranjivanje podataka da ulazno-izlaznu jedinicu.

---

<sup>4</sup> O ekspertnim sustavima i neuralnim mrežama ćemo malo detaljnije u daljnjem tekstu.

- 4) Alan Turing – često ga se spominje kao oca računalnih znanosti i umjetne inteligencije. Osmislio je Turingov stroj, koji se može prilagoditi da simulira logiku bilo kojeg računalnog algoritma pomoću manipulacije znakovima. Pomogao je tijekom Drugog svjetskog rata u dekodiranju njemačkog koda koji su njihove vojske slale svojim postrojbama koje su bombardirale Veliku Britaniju, smatra se da je tim dostignućem postigao da rat traje dvije godine kraće. Također je izmislio Turingov test koji služi za provjeravanje inteligencije računala i njegove svjesnosti, razlučuje se da li stroj može zavarati čovjeka da je stvarna osoba pomoću korištenja prirodnog jezika.
- 5) „Dartmouth Conference“ – 1955. John McCarthy je organizirao grupu kako bi se razjasnile i razvile ideje o strojevima koji razmišljaju i na taj način je područje dobilo ime "Umjetna inteligencija". U ljeto 1956. na Dartmouth Collegeu se održala konferencija koja je trajala mjesec dana, u kojem se odvijao istraživački projekt o umjetnoj inteligenciji, smatra se jednim od bitnih događaja koji su doveli do završnog oblikovanja tog znanstvenog područja. Nakon čega je uslijedilo mnogo velikih otkrića i postignuća poput Elize, koja je bila prvih Chatbot, lansiranja Sputnika i sl.
- 6) Razdoblje umjetne inteligencije – Chace tu apelira na "Zime umjetne inteligencije", odnosno na razdoblje između 1973. i ranih '80-ih, gdje dolazi do konstantnih uspona i padova te zamrzavanja ulaganja na području umjetne inteligencije. Između 1974. i 1980. te 1987. i 1993. se dogodilo više propalih ulaganja u istraživanja i izume pa su se prevelika očekivanja pretvorila u još veća razočarenja jer napredak nije bio dovoljno brz ili uspješan te su zbog krivih pretpostavki vladine organizacije i investitori počeli ukidati sredstva koja bili spremni uložiti. 2000-ih je čak dolazilo do toga da bi istraživači davali drugačija imena svojim područjima proučavanja kako bi naglasili da je njihovo istraživanje usmjereno prema nečem određenom, kako bi se maknuli od stigmatizacije naziva "umjetna inteligencija". Tako se interes za tim područjem i njenim financiranjem stalno mijenjao: prvo bi nastala velika očekivanja, zatim uslijedila razočaranja i ukidanja financiranja, dok ponovno ne bi došlo do nekog većeg pomaka u istraživanjima te ponovnog zanimanja ulagača, i tako u krug, iako se područje umjetne inteligencije kroz sve ove godine pokazalo kao vrlo napredno i korisno u više segmenata.
- 7) Umjetna inteligencija u Hollywoodu – razdoblje koje je i dalje aktualno, a to su filmske reprezentacije umjetne inteligencije.<sup>5</sup>

---

<sup>5</sup> O toj fazi ćemo malo opširnije na samom kraju problematiziranja društvenih implikacija razvoja umjetne inteligencije.





## 4. PRIMJENJENE METODE U UMJETNOJ INTELIGENCIJI

Kao koncept, termin *metoda* se na području umjetne inteligencije koristi u značenju definiranja načina na koji se izvršava kodiranje, generalno programiranje sustava te način na koji će sustav učiti. Ovisno o tome za što je stroj namijenjen, koje je optimalno rješenje za njegovu izvedbu te što ga točno želimo naučiti i na koji način želimo da izvršava zadane naredbe.

Tijekom razvoja područja umjetne inteligencije pokazalo se kako postoje dva osnovna pristupa, odnosno metode koje se primjenjuju a to su klasične (*top-down* pristup, ekspertni sustavi) i suvremene metode (*bottom-up* pristup, neuralne mreže).

### 4.1. Klasične metode u umjetnoj inteligenciji

Kada je riječ o klasičnom obliku umjetne inteligencije zasigurno se može reći da se ista zasniva na simboličkom pristupu i metodi. Temeljni postulat od kojeg se polazi je inteligentno ponašanje koje se postiže razvojem logičnog zaključivanja definiranog skupom normi.

U klasičnom obliku umjetne inteligencije primjenjuje se *top-down* pristup, čija je glavna osnova – znanje stečeno kroz simbole. Isto tako polazi od pretpostavke da se inteligentno ponašanje postiže isključivo spoznajom na način da se prikupljeni simboli iz svijeta koji nas okružuje budu analizirani. Drugim riječima, *top-down* pristup se zasniva na svojstvu da se veliki problem rješava s nekoliko malih rješenja, odnosno nastoji se što više pojednostaviti rješavanje problema (Russell, Norvig, 2010).

Metode koje se primjenjuju u klasičnom obliku umjetne inteligencije su:

- modeliranje prilikom odlučivanja
- stvaranje ekspertnih sustava ili stabla odlučivanja

Kada govorimo o konceptu ekspertnog sustava može se reći da se isti zasniva na strojnom funkcioniranju, odnosno na prosuđivanju i obrađivanju činjenica iz određene domene. Da bi se svi podaci i činjenice obradile računalu je potrebna određena baza podataka na temelju koje vrši svoje radnje.

Jedan od prvih ekspertnih sustava koji je bio oformljen bio je medicinski sustav poznatiji kao MYCIN (ime je dobio po tome što većina naziva antibiotika završava sa sufiksom -mycin), a koristio se u svrhu dijagnostike krvnih infekcija. Sadržavao je otprilike

500 pravila te se smatralo da je bolji i uspješniji u postavljanju dijagnoze nego mladi liječnici. Većina pravila na kojima se temeljio MYCIN i koja su se provodila u sustavu MYCIN nisu bila teorijski generirana, već su bila sastavljena nakon provedenih razgovora sa brojnim stručnjacima (Shi, 2011).

Navedene metode imaju svoje prednosti i nedostatke. Ekspertni sustav, odnosno stablo odlučivanja tijekom provođenja ove metode, u praksi se pokazalo kao nesigurno zbog brojnih normi koje su nametnute kao obvezne. Pored velikog broja normi na takvu praksu je zasigurno utjecala i neizvjesnost, odnosno nemogućnost predviđanja situacije prilikom primjene određenih pravila. Obzirom da metode klasičnog oblika umjetne inteligencije nisu polučile željene učinke dolazi do stvaranja cijelog sustava novih metoda koje mogu savladati nove izazove.

Jedan od prvih uspješnih komercijalnih ekspertnih sustava je bio R1, koji je pomagao u konfiguraciji narudžbi novih računalnih sustava, s vremenom je tvrtka pomoću R1 uspjela uštediti i do 40 milijuna dolara godišnje (Russell i Norvig, 2010).

Najveći nedostatak ekspertnog sustava je što prilikom obrade i pohrane brojnih podataka baza postaje pretrpana. Klasične metode su dobre kada se primjenjuju na računalima ili robotima, odnosno za definiranje radnih zadataka jer propisane norme treba primijeniti u kratkom periodu. Više su predviđeni kao neka vrsta alata ili posrednika, primjerice ako se radi o medicinskom ekspertnom sustavu, doktor je taj koji će upravljati njime te krajnji korisnik, odnosno pacijent neće imati nikakvog doticaja sa samim sustavom. Doktor odlučuje hoće li ili neće prihvatiti sugestije koje mu sustav nudi no bilo kakva akcija ekspertnog sustava nema utjecaja na pacijentovo ponašanje, već na doktorovo koje će on potom prenijeti na pacijenta (Russell i Norvig, 2010).

#### **4.2. Suvremene metode u umjetnoj inteligenciji**

U posljednjem desetljeću sve više se umjetnoj inteligenciji pristupa suvremenim metodama, a iste su usmjerene na *bottom-up* tehniku (Russell, Norvig, 2010).

*Bottom-up* tehnika obuhvaća gradbene blokove inteligencije, koji se zajedno povezuju u cjelinu u određenoj situaciji na način da ih se ostavi da uče i razvijaju se u određenom vremenskom periodu nakon kojeg se provjere dobiveni podaci. Ta tehnika je nastala kroz posljednja dva desetljeća s ciljem izgradnje inteligentnih agenata, koji bi olakšali posao čovjeku i koji bi kao takvi bili uspješni u svojoj okolini.

Osnova *bottom-up* metode se odnosi na kombiniranom ponašanju. Na takav način bi se osposobili novi strojevi koji uz pomoć dovoljnih motornih vještina i senzornom interakcijom s okolinom mogli bez problema obavljati poslove za koje su programirani (Russell, Norvig, 2010). Dakle, naglašava se važnost da se kreira model interakcije entiteta i njihove okoline. Inteligentno i odgovorno ponašanje entiteta postizalo bi se na način da bi se povezivali u jednostavne procese, a funkcionirali bi na principu senzora koji očitavaju neurone u mozgu i druge reakcije, odnosno podražaje.

#### 4.2.1. Neuralne mreže

Primarno područje koje se istražuje u suvremenim teorijama na području umjetne inteligencije su neuralne mreže, temeljni koncept rada neuralnih mreža moguće je razmotriti način rada biološkog mozga u smislu; osnovnih funkcija, razvoja i prilagodbe tijekom vremena.

Model koji oponaša biološku neuralnu mrežu nazivamo umjetnim neuralnim mrežama. Današnje neuralno procjenjivanje koristi jako ograničen set koncepata utemeljen na našem znanju o biološkom neuralnom sustavu. Umjetni neuron funkcionira na principu biološkog neurona. U ljudskom mozgu su oni su zaduženi za funkcije koje su povezane sa živčani sustavom, međusobno su povezani (Dalbello Bašić *et. al.*, 2008).

Dakle, umjetne neuralne mreže su inspirirane proučavanjem mozga i živčanog sustava. Rezultati funkcioniranja takve vrste mreže bili bi zastupanje znanja u golemim paralelnim procesiranjima, brz povrat velikog broja informacija, te sposobnost prepoznavanja uzorka baziranih na iskustvu.

Dalbello Bašić i suradnici (2008) opisuju način na koji mreža uči. Svaki neuron zaprima unose, procesira ih i izbacuje jedan rezultat. Relevantne informacije mogu biti procesirane jednom kad se osnuje struktura mreže. Glavni elementi koji sudjeluju u procesiranju su: *unosi (input)*, *rezultati tj. proizvodi (output)* i *ponderi (weights)* - ponderi iskazuju relativnu važnost svakog unosa za element procesiranja. Oni su neizostavni jer se kroz konstantno prilagođavanje pondera mreža „uči“.

Funkcija zbrajanja nalazi težinski prosjek svih elemenata unosa za svaki element procesiranja i izračunava unutrašnju stimulaciju, ili razinu aktivacije, neurona. Veza između unutarnjeg aktivacijskog nivoa i rezultata može biti linearna ili nelinearna. Takve veze su izražene funkcijom transformacije (transfera) i postoji nekoliko različitih vrsta. Odabir

određene funkcije determinira rad mreže. Transformacija se može pojaviti na rezultat svakog elementa procesiranja ili može biti izvršena na posljednjem rezultatu mreže.

Prva dva koraka u procesu razvoja umjetnih neuralnih mreža povezani su sa sakupljanjem podataka te njihovim dijeljenjem na set za treniranje i set za testiranje. Podaci koji služe za treniranje se koriste za prilagodbu pondera. Dok se podaci za testiranje koriste za provjeru valjanosti mreže. Visokokvalitetan skup podataka služi za smanjenje pristranosti, pogrešaka, i nasumičnosti u podacima, kako bi bilo pokriveno što više mogućih problema. Što se više podataka koristi to je bolje, dok god se ne žrtvuje kvaliteta.

Struktura mreže izgleda tako da se svaka umjetna neuralna mreža sastoji od zbirke neurona grupiranih u slojeve. Prema Dalbelo Bašić i suradnicima (2008) razlikujemo četiri osnovne arhitekture, a to su: aciklička, mreža s povratnom vezom, lateralno povezana mreža te hibridne mreže.

Medsker i suradnici (1993) pišu kako je osnovna struktura ona koja ima tri sloja: unos, posrednik (tzv. skrivena razina) i rezultat. Razvijeno je mnogo različitih modela i implementacija neuralnih mreža, tu su neki od primjera: asocijativni memorijski sustav ima sposobnost prisjećanja potpunih situacija iz djelomičnih informacija. Ti sustavi povezuju unesene podatke sa informacijama pohranjenim u memoriji te mogu imati jednog ili više posrednika (skrivenih) slojeva. Jedan od oblika učenja je onaj bez nadzora, sposoban je učiti tako da mijenja pondere u prepoznavanju kategorija unesenih podataka bez da su mu osigurani primjeri od vanjskog trenera. Struktura duplog sloja ne zahtijeva znanje točnog broja razreda u podacima za treniranje. Umjesto tog koristi prepoznavanje unaprijed i unazad (*feed-forward, feed-backward*) da prilagodi parametre tijekom analiziranja podataka.

Medsker i suradnici (1993) također napominju kako je važna je prikladna upotreba algoritama za učenje (ili treniranje), a poznato ih je preko tisuću. Tu taksonomiju je predložio Lippman, i stavlja razliku između dvije glavne kategorije formata unosa: unos binarne vrijednosti (nule i jedinice) ili unos kontinuirane vrijednosti.

Treniranje mreže se sastoji od predstavljanja mreži seta podataka za treniranje kako bi ponderi mogli biti prilagođeni da proizvedu željeni rezultat za svaki unos. Izbor strukture mreže (npr. broj čvorišta i slojeva), kao i odabir inicijalnih uvjeta te mreže, determinira vrijeme potrebno za trening, ovisno o tome koliko je ponavljanja potrebno dok se ne razvije konzistentan set pondera koji se može upotrijebiti za sve podatke treniranja.

Nakon što se obavi trening, potrebno je testirati mrežu. Mjeri se sposobnost mreže da li će točno klasificirati testne podatke. U slučaju da se testiranjem otkriju velika odstupanja, set za treniranje se mora ponovno pregledati i proces treniranja će se možda morati ponovno aktivirati, dok rezultati ne budu zadovoljavajući (Dalbello Bašić *et. al.*, 2008).

Medsker i suradnici (1993) daju ukratko prikaz funkcioniranja i važnosti primjenjivanja nekih elemenata. U izradi umjetne neuralne mreže, moraju biti donesene mnoge odluke od kojih su najvažnije: veličina podataka za treniranje i testiranje, algoritmi učenja, topologija – broj elemenata za procesiranje i njihovih konfiguracija (unos, slojevi, rezultati), odabir funkcije transformacije (transfera), omjer učenja za pojedini sloj, odabir dijagnostičkog i vrednujućeg alata. Specifičan skup konfiguracija koje su determinirane tim odlukama se nazivaju paradigma mreže.

Umjetne neuralne mreže mogu biti programirane programerskim jezikom, alatom ili oboje. Veliki dio programiranja se bavi s algoritmima treniranja, i funkcijama transfera i zbrajanja.

Većina aplikacija neuralnih mreža uključuje simulaciju softvera koji radi na konvencionalnom dosljednom (sekvencijskom) procesoru. Simuliranje neuralnih mreža znači matematičko definiranje čvorišta i pondera koji su im pripisani, stoga se za sve neurone koristi jedan procesor (umjesto tog da svaki neuron koristi svoj zasebni procesor). Takve simulacije zahtijevaju dugo procesiranje. Unapređenja hardverske tehnologije će omogućiti veću potražnju od memorije i brzine procesiranja te će pružiti kraće vrijeme treniranja većih mreža.

Tehnologija umjetnih neuralnih mreža je u današnje vrijeme vodeći koncept u području razvoja inteligentnih sustava.

Prema Warwicku (2004) cilj područja umjetne inteligencije je tražiti inspiraciju iz biološkog načina djelovanja mozga kako bi ga se moglo primijeniti na tehnološkom dizajnu. Na taj način umjetna tj. tehnološka verzija zapravo koristi prednosti biološkog mozga, primjerice sposobnosti generalizacije ili kategoriziranja pojedinih događaja u neku od mogućih kategorija. Ujedno postavlja pitanje što će biti s čovječanstvom ukoliko se dogodi toliki napredak da strojevi postanu inteligentniji od ljudi.

U sljedećem poglavlju ćemo se baviti problematiziranjem takvih ili sličnih stajališta te razraditi temu predrasuda i strahova, pozitivnih i negativnih aspekata koji su vezani uz razvoj umjetne inteligencije.

## **5. BUDUĆE IMPLIKACIJE RAZVOJA UMJETNE INTELIGENCIJE**

Umjetna inteligencija već desetljećima je predmet znanstvene fantastike, no mnogi istraživači misle da se konačno približavamo stvarnosti umjetne inteligencije. Znanstvenici su u posljednjih nekoliko godina napravili proboj u "strojnom učenju", koristeći već ranije navedene neuralne mreže.

Sa znanstvenog aspekta umjetna inteligencija je vrsta "dubokog učenja" koja omogućuje strojevima da obrađuju informacije za sebe na vrlo sofisticiranoj razini, omogućujući im da obavljaju složene funkcije poput prepoznavanja lica. Velike baze podataka ubrzavaju razvoj procesa algoritma i u bliskoj budućnosti će se brzo vidjeti složenije tehnološke integracije umjetne inteligencije u našem svakodnevnom životu. Iako je većina ove tehnologije još uvijek prilično rudimentarna u ovom trenutku, možemo očekivati da sofisticirani oblici umjetne inteligencije u bliskoj budućnosti značajno utječu na naš svakodnevni život.

Postoji nekoliko pretpostavki na koje bi umjetna inteligencija mogla utjecati u našoj budućnosti prilikom obavljanja svakodnevnih aktivnosti, ovo su samo neke od njih.

Jedna od tih stavki je automatizirani prijevoz te ono što je jedan od najvećih koristi razvoja umjetne inteligencije jest automatizirano preuzimanje poslova koji su riskantni ili opasni za ljude. Na taj način će se uvelike smanjiti potencijalna mogućnost za ozljeđivanjem ili razvijanjem bolesti koje se mogu pojaviti na dugogodišnjem radnom mjestu teškog fizičkog rada i neadekvatnih uvjeta.

### **5.1. Automatizacija prijevoza**

Za početak ćemo se baviti kratkim prikazom napretka automatizacije prijevoza:

„DARPA Grand Challenge“ – 2005. godine, Stanfordovo autonomno vozilo je prešlo 210 kilometara po neuvježbanoj pustinjskoj stazi. Dvije godine prije tog nijedno vozilo nije moglo preći više od 11 kilometara.

DARPA Grand Challenge – 2007. godine, CMU vozilo je prešlo 88 kilometara u urbanom okruženju dok se pridržavalo prometnih zakona i pazilo na potencijalne prometne opasnosti.

"Google Car", kojeg u današnje vrijeme ga nazivaju „Waymo“ je projekt star gotovo jedno desetljeće, do sada je samostalno odvezio već nekoliko milijuna kilometara te se priprema na komercijalizaciju ove ili sljedeće godine.

Moshe Y. Vardi (2017) kaže da je prošle godine tridesetak tvrtki radilo na proizvodnji samohodnih automobila. Smatra da će tehnološki problemi biti razriješeni u razdoblju između 5 do 15 godina te se mora poraditi na zakonskim i pravnim pitanjima. Neki od problema koji se pojavljuju veliki gubitak u poslovanju na nekim područjima kao što su to osiguravajuće ili odvjetničke tvrtke te gomila automobila koji će s vremenom postati sve više suvišni te će stvarati potencijalne probleme odlaganja otpada. Također je tu i masivan gubitak poslova, poput taksista i drugih poslova koji zahtijevaju vožnju (poštari, dostavljači i sl.) a s vremenom se planira automatizirati cijeli lanac opskrbe – teretni brodovi, pristaništa, kamioni, kamioni, dostava, itd. Kaže da 15 milijuna poslova u Americi uključuje upravljanje vozilom, 4 milijuna od tog su vozači taksija i kamiona.

No, naravno, Vardi (2017) vidi i puno pozitivnih strana automatiziranog prometa kao što su smanjenje broja prometnih nesreća, pomoć starijim osobama, slobodnije kretanje osoba s invaliditetom te mnoge druge.

Karen Levy (2017) je održala predavanje na Sveučilištu Cornell na temu sve većeg uvođenja robotike na radna mjesta te kako su se ljudi tome prilagodili. Smatra da iako možda robotika predstavlja neku prijetnju uzimanja poslova, ujedno i stvara sigurnost zbog velikog utjecaja na kvalitetu rada i pojednostavljenja zadataka.

Radila je kvalitativno istraživanje o tome kako uvođenje suvremene tehnologije na radna mjesta utječe na privatne i radne segmente radnikova života. Točke istraživanja su bile: kako radnici reagiraju na robotizaciju te kako se sadržaj i kvaliteta njihovog posla mijenjaju zbog tog, da li na neki način utječe na radnu dinamiku i socijalizaciju na radnom mjestu.

Za početak naglašava kako ne vjeruje da će strojevi odjednom preuzeti sve poslove, već će se taj proces odvijati jako sporo i postepeno te da će zapravo doći do hibridizacije robotskih i ljudskih sustava koji će koegzistirati i ovisiti jedni o drugima. Najviše pažnje je posvetila vozačima kamiona i toj industriji jer su ključni za funkcioniranje ekonomije (sve

što imamo na sebi, sa sobom ili u našim domovima, u nekom je trenutku moralo biti prevezeno kamionom), ali je užasno opasan i nepoželjan posao. U Sjedinjenim državama, to je posao koji stoji na osmom mjestu po riziku, opasnosti i ozljedama na radnom mjestu (puno zdravstvenih problema, dugi sati rada tijekom kojih sjede cijelo vrijeme, vozači se ne stignu zdravo hraniti, prisutna je visoka stopa dijabetesa, neregularan bioritam i sl.), stoga je potrebno nekako olakšati radnicima posao.

Levy (2017) kaže da se postepeno uvodi automatizacija koja bi trebala smanjiti broj radnih sati u komadu (što se zna nagomilati i po 30-35 sati te je samo po sebi velik rizik u koji vozač stavlja sebe, ali i sve druge sudionike u prometu), pojednostaviti neke zadatke kako bi mogli biti brže i lakše obavljeni, i potencijalno smanjiti radnikovu razinu stresa, odgovornosti te potencijalnih ozljeda.

Naglašava da uvođenjem robotizacije ne znači da će se eliminirati posao vozača, već će biti potrebno da koordiniraju svoj posao na drugačiji način. Primjerice da vozač obavlja sve druge usputne poslovne zadatke dok je vožnja automatizirana ili da vozač može dobiti upozorenje ukoliko se nalazi u nekoj problematičnoj situaciji npr. ako mu se počne spavati ili ako se nikako ne može održati budnim ili ako mu se zbog ukočenosti i bolova u kralježnici teško koncentrirati na vožnju, drugim riječima da vozači i roboti budu tim.

Tvrtka „Mercedes“ je najavila da radi na prsluku za vozače koji će pratiti njegove otkucaje srca i vitalne znakove te u slučaju da dođe do neregularnosti ili srčanog udara, vozilo bi se trebalo automatski zaustaviti. Još jedan način implementacije umjetne inteligencije dolazi od tvrtke „Seeing Machines“ koja koristi kameru koja nadzire vozačevo lice, njegove kapke te u slučaju da se dogodi da vozač na neko vrijeme zaklopi oči ili mu pogled odluta sa ceste, šalje se upozorenje njegovom šefu ili će prouzrokovati vibraciju u sjedalu u kamionu kako bi razbudilo ili alarmiralo vozača da se treba koncentrirati na vožnju.

Također je izumljena i kapa (*Smart Cap*) koja prati moždane valove, imitira EEG i registrira umor i slabost, ako se umore oglasit će se kako bi osvijestila vozača o tome da bude malo pažljiviji, oprezniji i više koncentriran. Isto tako se može konfigurirati tako da pošalje obavijest šefu ili menadžeru, ili čak vozačevoj obitelji.

Postoje i neki drugi sustavi koriste analitiku predvidljivosti pomoću koje se ustanovljuju šanse za neke određene situacije, primjerice daje upozorenja kolike su mogućnosti da se dođe do prometne nesreće na nekim područjima, i ne koristi samo podatke o



vožnji, već i neke bitne informacije i pojedinosti o vozačevom životu kako bi sustavi mogli na neke situacije preventivno djelovati.

Prema intervjuima koje je Levy (2017) provodila s vozačima kamiona, rečeno je kako oni svejedno nisu zadovoljni robotizacijom, pogotovo vozači sa duljim radnim stažem, iako je u svim ovim slučajevima zapravo od velike pomoći i koristi, ljudi teško prihvaćaju promjene. Element nepoznatog je ono što im zapravo stvara averziju prema automatizaciji te se osjećaju kao djeca ili kriminalci jer su pod nadzorom poslodavca i nadređenih. Ujedno su i napomenuli da se osjećaju kao da im netko zadire u privatan život i njihov dom jer to je ono što su njima kamioni kada su par dana, ako ne i tjedana, u komadu na cesti. Požalili su se i da im ponekad sve te tehnološke "spravice" odvrćaju pozornost od vožnje jer prečesto signaliziraju stvari. Dolazilo je čak do toga da vozači čekićem razbijaju uređaje, znali su se ujediniti i dogovoriti da će ih na određen dan strgati ili na neki način pokvariti, omesti signal i sl., čak su prije imali i forume na kojima su dijelili savjete kako pokvariti neke uređaje na najuvjerljiviji i najmanje primjetan način.

Levy (2017) smatra kako bi hibridizacija mogla bi pozitivna na radnim mjestima ukoliko smo osviješteni o sociokulturnom kontekstu područja u koje uvodimo umjetnu inteligenciju. Trebamo znati kada je u redu malo izmijeniti ili na neki način prekršiti pravila (ukoliko je potrebno, ako nas sustav ograničava u situacijama u kojima je to nepotrebno ili nepoželjno) te da ne bismo smjeli koristiti tehnologiju kao rješenje za probleme koji su fundamentalno komplicirani i imaju socioekonomsku dimenziju jer se onda upliće u vrlo kompleksan skup odnosa društvene moći i hijerarhije.

Iako je to pozitivno, puno ljudi je u strahu vezano za činjenicu da postoji mogućnost da će roboti početi zauzimati mjesta na sve više radnih pozicija te da će nezaposlenost porasti i time se povećati generalno nezadovoljstvo financijskim uvjetima te će doći do preispitivanja koja je ljudska svrha u životu ukoliko nećemo imati radna mjesta i neku vrstu karijere. Warwick (2004) je naglasio da je glavna poruka njegove knjige „*March of the machines*” da je stvarno moguće da se dogodi da strojevi preuzmu mjesto ljudi. Zbog takvih pretpostavki ljudi stvaraju predrasude i u većini slučajeva, krive pretpostavke vezane uz robotizaciju i napredak na području umjetne inteligencije. Iako je takav scenarij moguć, ne znači da će se dogoditi.

Unatoč negativnim pretpostavkama i zasada neopravdanim strahovima, Vardi (2017) kaže da će uvijek biti poslova za nisko i visoko plaćene pozicije u sektorima, netko mora

uvijek upravljati tvrtkom, nadgledati opće stanje, pozitivne i negativne situacije ili voditi istraživanja i sl., dok se nisko plaćene poslove ne isplati automatizirati jer su ulaganja u tehnološki razvoj i proces daleko preskupi. Za primjer je dao posao konobara koji je toliko malo plaćen da im se ne bi isplatilo investirati u kupovinu „automatiziranog robotskog konobara“ jer nikako ne bi bilo isplativo. Naglašava to kako je tehnologija uzimala ljudima poslove još od doba industrijske revolucije pa da su se novi poslovi i dalje otvarali te da će se vjerojatno socioekonomska situacija uspjeti prilagoditi novonastalim uvjetima kao što je i do sada kroz stoljeća uspijevala, adaptira se u tom trenutku aktualnim društvenim uvjetima te se stvaraju nova pravila, zakoni i potrebe. Jedno od mogućih rješenja je tema o kojoj se već neko vrijeme govori, a to je da svi pripadnici društva imaju „univerzalni osnovni dohodak“, na taj način će se moći osigurati da ljudi imaju novaca za svoje osnovne potrebe, bez obzira na napredak tehnologije i oduzimanje poslova te mnoge druge čimbenike, no to još nije ni blizu neke realizacije ili organiziranosti.

Chace (2015) govori o mogućnosti ideje „tehnološkog singulariteta“ prema kojoj se vjeruje da će super-inteligencija biti stvorena tijekom ovog stoljeća, u kojem će razina tehnološkog napretka biti toliko brza da je ljudi neće moći pratiti niti moći u potpunosti shvatiti.

Prije toga moramo brinuti o činjenici da će biti potrebno osmisliti novi ekonomski sustav ukoliko dođe do toga da će bilo koji posao moći biti bolje i brže obavljen od strane umjetne inteligencije te će većina ljudi ostati bez poslova pa ćemo morati pronaći drugačiji način nošenja s novonastalim stanjem, za koje vjeruje da je moguće čak i za našeg životnog vijeka. Chace (2015) argumentira kako umjetna inteligencija donosi jako širok spektar dobrobiti, ali ujedno i izazove, zato moramo promatrati promjene koje se događaju kako bismo bili spremni reagirati na vrijeme na potencijalne buduće promjene.

## **5.2. Implementacija umjetne inteligencije u svakodnevni život**

Daniel S. Weld (2017) govori o izazovima društveno korisne umjetne inteligencije, smatra da ishod može biti utopijski ukoliko se usmjerimo na poboljšanje nekih ključnih društvenih i tehničkih izazova. Također uzima primjer prijevoza, osim što napominje da je u prometu visoka stopa smrtnosti i ozljeda te da se pomoću tehnologije umjetne inteligencije može povećati sigurnost i smanjiti mogućnost potencijalnih prometnih nesreća, ujedno ukazuje i na to koliko se vremena dnevno troši na samo putovanje od doma do posla, u SAD-u je to u prosjeku 50 minuta dnevno.

Smatra da i na polju medicine ima dobrobiti od korištenja umjetne inteligencije jer se u Americi godišnje dogodi i do 250 000 smrtnih slučajeva zbog pogreški medicinskog osoblja, kojih bi zasigurno bilo u manjem broju kada bi ljudski rad mogao biti više potpomognut inteligentnom tehnologijom koja bi lakše i brže mogla predvidjeti moguće pogreške ili krive dijagnoze. Također vidi veliku korist umjetne inteligencije i na drugim područjima svakodnevnog života – kao što su personalizirana edukacija, sigurnija proizvodnja i sl.

Između ostaloga, citirao je i Stuarta Russella koji je izjavio kako će strojevi jednog dana doseći razinu inteligencije na kojoj će moći sami nastaviti raditi na umjetnoj inteligenciji te poboljšati i redizajnirati postojeće strojeve i hardvere kako bi dosegli vrhunac svog postojanja i učinili se najviše moguće intelligentnima.

Weld (2017) se ne slaže s takvim mišljenjima jer smatra da strojevi već sada imaju ljudske sposobnosti – računanje, igranje, provjera gramatičkih pogreški i sl., štoviše u tome su puno sposobniji nego ljudi, ali naglašava da taj napredak ide postepeno te da su strojevi možda super inteligentni na jednom području za koje su dizajnirani, no glupi su i nesposobni za sva ostala područja. Drugim riječima, njihova inteligencija se povećava samo na određenom području s kojim se ne proširuje znanje o svemu ostalom, čak ni na svome području ne pružaju sto posto točnosti, zato ih Weld naziva Idiotima Savantima (eng. *Idiot Savant*), uvijek postoji mogućnost pogreške. Dao je za primjer program „SquAD“ koji odlično funkcionira sa jednostavno postavljenim upitom i daje točan odgovor, no čim je pitanje malo kompliciranije formulirano, program izbacuje netočne odgovore.

Weld (2017) smatra da nam strojevi umjetne inteligencije ne žele niti će htjeti nauditi namjerno, no uvijek se može dogoditi da se omakne pogreška i dođe do slučajne ozljede te iz tog razloga bi se baš trebalo raditi na unapređenju tehnologije kako bismo ju učinili što inteligentnijom i umanjili mogućnost nesretnih slučajeva. Stoga je potrebno na taj način smanjiti rizik i nepredvidive situacije na minimum, kako stroj tijekom izvršavanja naredbe ne bi nekome nenamjerno naudilo ili naštetilo jer najveća opasnost umjetne inteligencije leži u njenoj nepredvidivosti.

Bitan je način na koji izdamo naredbu kako je robot ili stroj ne bi krivo protumačio (Weld, 2017). Primjerice ako robotu za čišćenje naredimo da počisti sav mogući nered, robot će vrlo vjerojatno početi sam stvarati nered kako bi ga imao što više za čistiti, ili ako je naredba da učini sobu čistom što je više moguće, da slučajno ne bi ozlijedio kućnog ljubimca

koji mu na podu predstavlja prepreku. Weld naglašava kako je bitno što više precizirati naredbu i specifično narediti robotu da počisti sobu bez da učini ikakvu štetu. Tu se primjenjuju tri Asimova zakona iz 1942., a to je da robot ne smije ozlijediti ljudsko biće ili dozvoliti da bude ozlijeđeno, zatim da robot mora izvršavati naredbe, osim ako se kose s prvim Asimovim zakonom te robot mora štiti svoje postojanje dok god to ne dolazi u konflikt s prva dva zakona.

Glavni problem se nalazi u tome što je jako teško definirati što je točno „ozljeda“ ili „šteta“ jer uključuje jako kompleksne značajke te je različiti ljudi poimaju na raznovrsne načine. Primjerice ako je netko alergičan na kikiriki, nekome kikiriki predstavlja problem i prijetnju dok osobi koja nema takvu alergiju oprez s kikirikijem nije potrebno naglasiti u naredbi. Potrebno je ponašanje sustava ili agenta ograničiti na neki način te bi sustav s vremenom i iskustvom sam trebao učiti nove zabrane i prilagođavati se novim situacijama jer svaki pojedinac ima drugačije potrebe i želje. Weld (2017) predlaže dva ključna načina postavljanja granica, jedan od njih je dijalog, tj. da nam sustav postavlja potpitanja dok naredba nije u potpunosti jasna i maksimalno ograničena. Drugi način je da mu postavimo lokalnu točnost, odnosno da mu omogućimo jednostavno objašnjenje za pojedinu situaciju koju može onda primijeniti na različite situacije koje imaju takve sličnosti s određenim područjem, iako ne pruža globalno rješenje, barem ga ograničava da ne napravi neke pogreške na tim poljima. Osim robota koji su nam korisni u radnom segmentu života, sve su češća pojava oni koji imaju svrhe i u privatnom.

Jedan od primjera za robota prijatelja je Pepper, koji je predstavljen na konferenciji 2014. godine, a pušten je u prodaju 2016. u Ujedinjenom kraljevstvu. Sposoban je pokazati emocije jer ima sposobnost analiziranja izraza lica i tona glasa, na taj način zna koje je najbolje ponašanje prikladno za trenutnu situaciju. Služi tome da čini ljude sretnima, ali ujedno može biti koristan i na nekim radnim mjestima, u Ujedinjenom kraljevstvu radi na mjestu recepcionara u nekim uredima, osim nekih osnovnih poslova, može i komunicirati sa klijentima. U Japanu ga koriste čak i u bankama i zdravstvenim ustanovama te restoranima.

Također 2017. godine „AvatarMind Robot Technology“ je proizveo robotskog prijatelja koji je namijenjen za djecu, nazvan „iPal“. Osmišljen je prvenstveno kao edukacijsko sredstvo, ali ujedno da i djetetu pravi društvo. Sposoban je da, između ostalog, poučava matematiku, potiče socijalni razvoj te potiče na interes za znanosti i tehnologijom, no također ima i zabavnu stranu gdje može plesati, pričati priče, igrati igre i poticati na fizičku aktivnost,

a roditelji konstantno mogu kontrolirati i nadgledati napredak svog djeteta putem svojih pametnih telefona ili računala. Ujedno je namijenjen i kao društvo i terapija za djecu s posebnim potrebama kao što je autizam.

Ono što je još jedna društvena prednost u napretku područja umjetne inteligencije je poboljšana skrb za starije građanstvo. Mnogi od njih se teško snalaze u starosti, potrebna im je pomoć, u dosta slučajeva i stručna medicinska skrb te se onda moraju osloniti na članove obitelji ili platiti stručnom osoblju da se brinu za njih.

Već ranije navedeni prijateljski robot „iPal“ može služiti i kao društvo za starije osobe, ujedno bilježi i njihove svakodnevne aktivnosti, poput uzimanja lijekova te pruža brigu i sigurnost jer može medicinskom osoblju javiti bilo kakve medicinske tegobe ili nesretne slučajeve kao što je padanje, kada osoba ne može sama tražiti pomoć.

### **5.3. Emocionalna veza između ljudi i strojeva**

Ross Knepper (2017) govori o emocionalnim povezanostima s robotima, postavlja pitanje da li je takav odnos neizbježan te kako će utjecati na ljudsko ponašanje. Istražuje probleme poput okrutnosti prema robotima, seks robotima i robotima koji su stvoreni za zaštitu ili vojnu dužnost, odnosno etičnosti robotike generalno.

Koje sve odlike robot mora imati kako bi se slagao ili povezao s ljudskim bićem? Bitan je način na koji je utjelovljen izgled robota, to Knepper (2017) smatra jednom od bitnijih stavki na koje ljudi gledaju – da li robot ima simpatičnu vanjštinu ili izgleda prijeteće. Druga stavka je autonomija, ne na način da imaju slobodnu volju, ali da su sposobni obavljati zadatke za koje ih je čovjek zadužio. Treće je da funkcioniraju kao agenti ili činitelji tj. da imaju sposobnost samostalnog donošenja odluka. Kada se ta tri segmenta spoje, dolazi do antropomorfčnosti<sup>6</sup>.

Knepper (2017) je također dao primjer „IkeaBota“ u kojem postoji mogućnost da dva robota međusobno surađuju, ali isto tako da su robot i čovjek suradnici, čemu se zapravo teži, a ne tome da postojanje jednog isključuje drugo.

Problem se pojavi ako dođe do kompleksnijih pitanja, zahtjeva ili dijaloga od strane čovjeka. Knepper (2017) kaže da kao programer može izjaviti koliko je zapravo teško

---

<sup>6</sup> Knepper (2017) je dao primjer Hollywooda i filma WALL-e. Tematika umjetne inteligencije se uklapa u gotovo svaki žanr: neki od njih su animirani, obiteljski i akcijski filmovi, drame, filmovi katastrofe pa čak i romantične komedije. Knepper je ukazao na to kako su usavršili dojam da se radi o pravim živim bićima i da bude u nama suosjećanje.

programirati robota koji će voditi iole normalan dijalog ili razumjeti neke dodatne upute, no kad mu daješ jasna, jednosmjerne upute, spreman je izvršiti zadatak i interakcija je puno jednostavnija. Problem tu proizlazi iz toga što dajemo robotima ljudske odlike i u interakciji očekujemo da će nas u potpunosti razumjeti ili imati korisnu povratnu informaciju, dok zapravo robota takav pristup samo može zablokirati ili potencijalno odvući u krivom smjeru izvršavanja zadataka.

Zanimljivo je to što su istraživanja pokazala da što je robot fizički više sličan realnom prikazu čovjeka, to nam je odbojniji te Knepper (2017) govori o pojmu „Uncanny Valley“. U ovom slučaju se to odnosi na osjećaj gađenja prema onome što nam izgleda čovjekoliko a prepoznamo da nije prava, stvarna osoba. Nije poznato zašto mozak doživljava stvari na taj način, pretpostavka je da nas asocira na smrt ili zombije i slično pa nam automatski stvara odbojnost, stoga može postojati problem ukoliko se uspije doseći ta razina tehnologije u kojoj će robot izgledati previše čovjekoliko.

Isti problem vrijedi i za životinjske robote, stvara se isti efekt u ljudskom mozgu, samo ne jednakim intenzitetom. Što nam govori da roboti ne moraju imati jednak fizički izgled poput ljudi da bi im dali ljudske osobine, štoviše, to može imati samo kontraefekt. Jedan od primjera koje je Knepper (2017) dao je robotski tuljan Paro, koji je bio iznimno popularan u Japanu, a predviđen je za pravljenje društva starijim osobama koje više nemaju toliko interakcija s drugim ljudima, smatra ga briljantnim dizajnom i da uistinu služi svojoj namjeni.

Nadalje govori o seks robotima, daje rezultate istraživanja koja su provedena u Americi gdje rezultati pokazuju kako su muškarci puno otvoreniji prema toj ideji nego što su žene. Ljudi gledaju na takvu vrstu robota više kao na samozadovoljavanje, a ne kao spolni odnos sa stvarnom osobom, iako iz dobivenih rezultata nije jasno da li je to zbog moralne prepreke jer možda to ne smatraju etičnim, ali ljudi žele nekako opravdati potrebu za postojanjem takvih robota. Ono što ljudi, prema nalazima istraživanja, priželjkuju od seks robota jest da su posebno dizajnirani da zadovolje seksualne potrebe, da se sami mogu kretati i da mogu primiti upute. Na drugu stranu, ono što je nepoželjno je to da imaju osjećaje, preuzimaju inicijativu i prepoznaju ljudske emocije. Naravno, bilo je neslaganja oko ženskih i muških mišljenja. Žene su više za to da seks robot može čuti, vidjeti i razumjeti jezik. Ispitanici su najčešće izjavili kako smatraju da bi ti roboti bili primjereni kao zamjena za prostituciju i sprječavanje širenja spolnih bolesti, no ujedno misle i da su neprimjereni za prakticiranje apstinencije i za seksualne prijestupnike. Zanimljivo je to što postaje sve više

prihvaćeno korištenje robota ne samo u poslovnoj i privatnoj, već i u intimnoj sferi života pojedinca.

Ono što je bitno je to da nam izgled robota daje osjećaj sigurnosti i povjerenja. Dao je za primjer robota („Georgia Tech“) koji je programiran da usmjerava ljude prema izlazu u slučaju požara, pokazalo se u vježbama da ga ljudi stvarno žele pratiti jer djeluje kao autoritet sa svoje dvije svjetleće palice (poput onih koje se koriste na aerodromima) pomoću kojih usmjerava, no iako ih u tom trenutku nije izveo na pravi put, ljudi su ga samovoljno željeli slijediti jer im ulijeva povjerenje svojom pojavom. To je bio eksperiment kojim su htjeli dokazati da ljudi mogu i previše vjerovati robotima.

Knepper (2017) zaključuje kako roboti uistinu mogu izazvati suosjećanje kod ljudi, ponajviše zbog svoje autonomije i utjelovljenja. Kompleksna emocionalna povezivanja su moguća, no moramo biti na oprezu kako netko ne bi iskoristio to za manipulaciju ljudima te smatra kako naše postupanje s robotima ujedno odražava i to kako se ponašamo jedni prema drugima.

#### **5.4. Umjetna inteligencija u Hollywoodu**

Chace (2015) tvrdi da Hollywood u svojim filmovima često prikazuje umjetnu inteligenciju u jako lošem svijetlu. Publici se predstavlja kao da je stvorena da uništi ljudsku rasu ili na neki način pokori čovječanstvo, u većini slučajeva ona je zla, ili zbog neispravnosti ili neke nužnosti naštetiti ljudima. Jedan od najpoznatijih filmova te vrste je „Terminator“, u kojem „Skynet“ želi uništiti čovječanstvo istog trenutka kada je doseglo razinu savjesti.

Iako se može naći i pokoji pozitivan primjer, u filmskoj industriji prevladava negativno gledište na napredak robotike i umjetne inteligencije (Chace, 2015). Moguće je da je to jedan od razloga zašto postoji strah i neka vrsta averzije nekih pojedinaca u društvu prema robotskoj industriji.

Prema svemu navedenom, možemo primijetiti kako velika većina stručnjaka zapravo ne vide nikakvu prijetnju u robotizaciji. Slažu se oko toga da je razvoj područja umjetne inteligencije prespor da bi imao nagli i neočekivani utjecaj na društvo. Smatraju kako će se ta tranzicija odvijati postepeno i da će svi akteri suvremenog društva imati dovoljno vremena za prilagodbu. Najveći problem leži u tome što ljudi strahuju od promjena te će ih samo neprihvatanje inovacija usporavati u bržem napretku i nepoželjnost suživota s inteligentnim strojevima i sustavima.





## 6. ZAKLJUČAK

Umjetna inteligencija predstavlja jedno kompleksno područje no još uvijek nedovoljno razvijeno. McCarthy, otac umjetne inteligencije, umjetnu inteligenciju definira kao znanost i inženjering za izradu inteligentnih strojeva, osobito inteligentnih računalnih programa, a radi se o sličnom zadatku korištenja računala za razumijevanje ljudske inteligencije, ali se umjetna inteligencija ne mora ograničiti samo na metode koje su biološki vidljive.

U tom smislu umjetna inteligencija se promatra kao znanost koja bi olakšala ponajviše svakodnevnu dnevnu rutinu pa su tijekom desetljeća istraživanja oformljene mnoge klasične i suvremene metode umjetne inteligencije. Budući da je predmet rada društvene implikacije umjetne inteligencije, naglasak je stavljen na suvremene metode umjetne inteligencije. Suvremene metode umjetne inteligencije počivaju na neuronskim mrežama, odnosno nastoji se stvoriti sustav tehnologije koji će imitirati rad ljudskih neurona.

Isto tako umjetna inteligencija u tom smislu se može promatrati s etičkog aspekta. Prema tvrdnjama i iznošenju mišljenja od strane profesora i stručnjaka na polju kibernetike Kevina Warwicka (2004), smatra se da bi umjetna inteligencija kroz razvoj robota mogla značajno naštetiti ljudima. Drugim riječima, tehnologija se ne bi smjela koristiti kao zamjena za ljude pogotovo kad se radi o javnim poduzećima. Ukoliko bi takva vrsta umjetne inteligencije u potpunosti zaživjela tada je sasvim jasno da bi roboti u potpunosti zamijenili čovjeka te on više ne bi imao razloga izvršavati svoje svakodnevne radne obaveze. U tom slučaju se samo nameće pitanje da li će društvo biti sposobno i spremno na adaptaciju jer u ovom slučaju doslovno sami kreiramo svoju sudbinu.

S obzirom na to da umjetna inteligencija sama po sebi nameće brojna moralna i etična pitanja jasno je da bi se buduće implikacije razvoja umjetne inteligencije morale uskladiti na globalnoj razini. Erdélyi i Goldsmith\_ (2018) su predložili osnivanje Međunarodne organizacije umjetne inteligencije koja bi služila kao međunarodni forum za diskusije i sudjelovala u predlaganju aktivnosti prema međunarodnim standardima te bi ujedinila raznoliku grupu sudionika koja bi se sastojala od javnog sektora, industrije i akademske zajednice, čija bi stručnost pomogla u donošenju važnih odluka regulacije zakona o umjetnoj inteligenciji.

Vjerujem kako su negativna gledišta prema razvitku umjetne inteligencije neispravna. Najčešći ljudski strahovi vezani uz umjetnu inteligenciju su neopravdani, dosad nije bilo nikakvih dokaza da postoji ikakva mogućnost da strojevi razviju vlastitu svijest ili da postoji

neki razlog i način na koji bi roboti samostalno htjeli nauditi ljudima. Društvo se kroz sva ova stoljeća uspjelo adaptirati na svakakve gospodarske i ekonomske promjene, stoga nema razloga da to neće biti slučaj i u situaciji s robotizacijom, ne mogu svi ostati bez poslova jer vjerujem da će se pojaviti nove vrste poslova koje će biti vezane za održavanje strojeva, kreiranje programa, dizajniranje sustava i sl.. Također smatram da će dugi niz godina biti financijski neisplativo većinu radnih mjesta zamijeniti robotima.

Smatram da je bitno da se na neki način preventivno zakonski regulira područje robotizacije i automatizacije kako ne bi došlo do neke vrste eksploatacije ili manipulacije ljudi putem inteligentnih sustava. Očito je da će to biti težak, zahtjevan i opsežan posao jer se radi o definiranju ogromnog broja pojmova i specifičnih situacija na koje bismo trebali biti spremni.

Budućnost će pokazati na koji će način umjetna inteligencija utjecati na razvoj i napredak ili nazadak društva, koje su pozitivne i negativne strane svih tih postignuća, da li je robotizacija dobra za poslovni segment ljudskih života s obzirom na to da nam pomaže u lakšem i bržem ostvarivanju poslovnih ciljeva i omogućuje više slobodnog vremena ili je zapravo loša jer ćemo svi u budućnosti biti zamijenjeni robotima i strojevima zbog kojih ćemo ostati bez primanja. S vremenom ćemo vidjeti da li je Warwick bio u pravu kada je 2004. upozoravao da postoji mogućnost da strojevi razviju vlastitu svijest, zavladaju svijetom i preuzmu ulogu ljudi ili nas zapravo čeka svijet pun lagodnosti i slobodnog vremena.

## 7. POPIS LITERATURE

Casti, J.L. i KarlQvist, A., ur. (1987) *Real Brains: Artificial Minds*, New York ; Amsterdam ; London : Elsevier Science Publishing Co.

Chace, C. (2015) *Surviving AI : The promise and the peril of artificial intelligence*, [s.l.] : Three Cs.

Dennett, D. C. (1982) The Myth of the Computer : An Exchange. *The New York Review of Books*. April 1982, Vol. 29, No. 11.

Dorffner, G., ur. (1997) *Neural Networks and a New Artificial Intelligence*. London ; Bonn ; Boston : International Thompson Computer Press.

Dreyfus, H.L. (1992) *What computers still can't do: a critique of artificial reason*. Cambridge, Mass. ; London : The MIT Press, cop.

Hebb, D. O. (1949) *The Organization of Behavior : A Neuropsychological Theory*. New York : John Wiley & Sons, Inc. ; London : Chapman & Hall, Limited.

McCarthy, J. (2007) What is artificial intelligence? <http://jmc.stanford.edu/artificial-intelligence/index.html> (16. 08. 2018.)

Medsker, L., Turban, E., Trippi, R.R. (1993) Neural Network Fundamentals for Financial Analysts. *The Journal of Investing*. Spring 1993, Vol. 2, 59-68.

Piccinini, G. (2004) The First Computational Theory of Mind and Brain : A Close Look at Mcculloch and Pitts's "Logical Calculus of Ideas Immanent in Nervous Activity. *Synthese*. August 2004, Vol. 141, 153-285.

Rajani, S. (2011) *Artificial intelligence: Man or machine*. International Journal of Information Technology and Knowledge Management. January-June 2011, Vol. 4, No. 1, 173-176.

Russell, S. J. i Norvig P. (2010) *Artificial intelligence: a modern approach*. 3. Ed. Upper Saddle River, NJ : Prentice-Hall.

Searle, John. R. (1980) Minds, brains, and programs. *Behavioral and Brain Sciences*. Vol. 3, No. 3, 417-457.

Shi, Z. (2011) *Advanced Artificial Intelligence : Series on Intelligence Science — Vol. 1*. Singapore : World Scientific Publishing Co. Pte. Ltd.

Singbo, O.G. (2009) *Umjetna inteligencija u suvremenom biokibernetičkom sustavu*. Spectrum. Siječanj 2009, No. 3-4, 55-63.

Warwick, K. (2004) *March of the machines: The breakthrough in Artificial Intelligence*. 2.ed. University of Illinois Press, Urbana and Chicago : First Illinois paperback.

Wiener, N. (1964) *Kibernetika i društvo : ljudska upotreba ljudskih bića*. Beograd : Nolit.

Internetski izvori:

[http://www.aies-conference.com/wp-content/papers/main/AIES\\_2018\\_paper\\_13.pdf](http://www.aies-conference.com/wp-content/papers/main/AIES_2018_paper_13.pdf) (14. 07. 2018.)

Levy, K. (2017) *Working with and against AI* <http://www.cornell.edu/video/karen-levy-working-with-and-against-ai-artificial-intelligence> (28. 10. 2018.)

Knepper, R. (2017) *Autonomy embodiment anthropomorphism : The ethics of robotics* <http://www.cornell.edu/video/ross-knepper-autonomy-embodiment-anthropomorphism-ethics-robotics> (22. 10. 2018.)

Vardi, M. (2017) *Humans, machines, and work : The future is now* <http://www.cornell.edu/video/moshe-varidi-humans-machines-and-work> (06. 09 .2018)

Weld, D. (2017) *Challenges for Socially-beneficial AI* <http://www.cornell.edu/video/dan-weld-challenges-for-socially-beneficial-artificial-intelligence> (30. 10. 2018.)

<https://www.frontiersin.org/articles/10.3389/fncir.2013.00057/full> (08. 09. 2018.)

<https://futureoflife.org/> (08. 09. 2018.)

<https://www.hindawi.com/journals/aans/2015/421215/> (19. 05. 2018.)

<https://www.gatech.edu/> (30. 10. 2018.)

<https://www.techemergence.com/artificial-intelligence-industry-an-overview-by-segment/> (01. 06. 2018.)